

# Aprendizado de Máquina no Estudo de Explosões Solares: Um Panorama da Produção Científica Brasileira

Marcos W. S. Oliveira<sup>1</sup>

GPMCC/IFSP e DIHPA/CGCE/INPE, São José dos Campos, SP

Tiago M. Ferrer<sup>2</sup> Paulo J. A. Simões<sup>3</sup>

CRAAM/Mackenzie, São Paulo, SP

Marlos R. Silva<sup>4</sup> Luis E. A. Vieira<sup>5</sup>

DIHPA/CGCE/INPE, São José dos Campos, SP

**Resumo.** Este trabalho tem por objetivo apresentar a área de Física Solar, em especial o fenômeno de explosões solares, como oportuna para pesquisas futuras envolvendo aprendizado de máquina. Ocorre que extensos conjuntos de dados dessa área estão disponíveis e a produção científica brasileira recente é de 1,88% ante à mundial, abaixo da porcentagem vista em outras áreas. Para tanto, o artigo contém descrições sobre o fenômeno físico, incluindo suas classificações e referências de fontes de dados. Também apresenta conceitos de aprendizado de máquina e trabalhos recentes envolvendo as duas áreas. Por fim, discute levantamento de produção científica e instituições nacionais nessa linha de pesquisa, visando facilitar interações entre atuais e novos pesquisadores.

**Palavras-chave.** Aprendizado de Máquina, Atividade Solar, Clima Espacial, Explosões Solares, Periódicos CAPES.

## 1 Introdução

O Aprendizado de Máquina tornou-se essencial na era do *big data*. A Astrofísica, Física Solar e Clima Espacial são áreas propícias para sua aplicação. Nessas áreas, dados *in situ* e remotos vêm sendo coletados ao longo de décadas por missões espaciais e terrestres, produzindo extensos conjuntos de dados livremente disponíveis [3]. Haja vista que seus estudos dependem de observações cujas condições experimentais não podem ser alteradas, apenas observadas [1].

Fenômenos como explosões solares (*solar flares*) e ejeção coronal de massa (*coronal mass ejection*, CME) podem parecer distantes, mas suas consequências danificam satélites e afetam tecnologias terrestres [17]. Prevenir-se para eventos perigosos como o “Evento *Starlink*” e em “Quebec 1989” [7], torna-se crucial para a manutenção da sociedade tecnológica contemporânea [1]. Nesse contexto, a Figura 1 traz observações de uma explosão solar pelo satélite SDO (*Solar Dynamics Observatory*), além de uma concepção artística do plasma solar colidindo com o campo geomagnético.

A aplicação de técnicas de aprendizado de máquina tem grande potencial de melhoria no entendimento em Física Solar [1]. Além disso, pesquisas nessa área com enfoque nacional mostram-se estratégicas. Sendo assim, este artigo revisa conceitos de aprendizado de máquina e explosões solares, além de analisar a produção científica recente de pesquisadores em instituições brasileiras. Espera-se, portanto, incentivar novas pesquisas e formação de recursos humanos nessa linha.

---

<sup>1</sup>oliveiramw@ifsp.edu.br

<sup>2</sup>ferrertiago@gmail.com

<sup>3</sup>paulo@craam.mackenzie.br

<sup>4</sup>marlos.silva@inpe.br

<sup>5</sup>luis.vieira@inpe.br




Figura 1: a) Composição de observações de uma explosão solar. b) Representação artística de plasma solar colidindo com o campo magnético da Terra. Fonte: adaptado de [17].

## 2 Explosões Solares

Explosões solares são fenômenos energéticos que causam aumento de radiação, particularmente em comprimentos de onda curtos, sendo considerados o início para muitos fenômenos e impactos no Clima Espacial [9]. Esses eventos resultam da liberação e dissipação de energia magnética na atmosfera do Sol, com aumento da intensidade da radiação no espectro eletromagnético [6]. Especificamente, entende-se que a reconexão magnética seja o mecanismo de liberação dessa energia [9]. Segundo Priest e Forbes [14], na reconexão ocorrem quebras nas linhas de força magnética, conforme representado nas Figuras 2a e 2b. Essa quebra provoca que parte do plasma seja ejetada para fora do Sol e outra parte volte para sua superfície. O primeiro movimento corresponde à CME (Figura 2c) e o plasma magnetizado é levado pelo vento solar ao meio interplanetário, tornando-se ICME (*interplanetary coronal mass ejection*) [16].


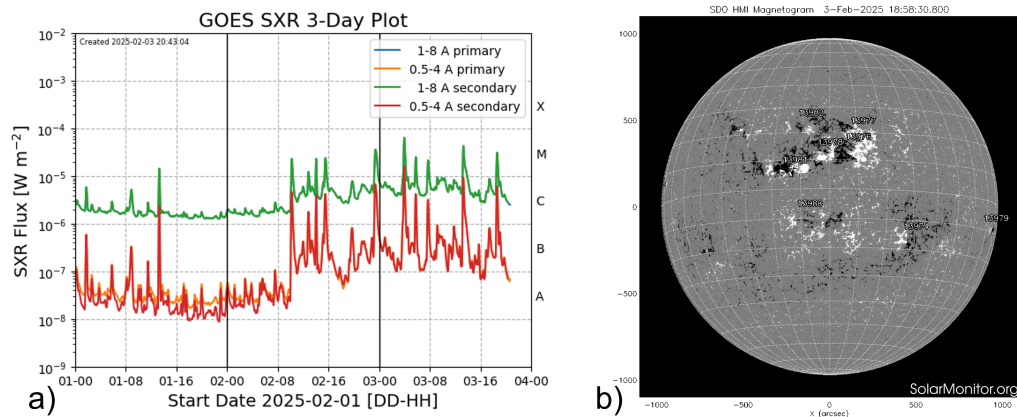


Figura 2: Evolução do comportamento das linhas de campo magnético de regiões ativas do Sol em duas fases (a,b) tendendo à reconexão magnética e representação de explosões solares com características observacionais (c). Fonte: adaptado de [14].

Dependendo da orientação das linhas de campo no plasma solar na ICME, pode haver interação com o campo magnético terrestre, ocasionando reconexão magnética nos polos e na cauda. Nesse caso, similar ao representado na Figura 1b, o plasma na ICME se expande no meio interplanetário e, se direcionado à Terra, pode interagir com o campo geomagnético, causando precipitação de partículas, tempestades geomagnéticas, auroras e outros fenômenos [7, 17]. Enquanto a radiação emitida numa explosão solar leva cerca de 8 minutos para chegar à Terra, as ICMEs levam cerca de 2 ~ 3 dias. Tem-se aqui, nessa escala de tempo, uma justificativa para estudar explosões solares como previsão de ICME e eventos extremos [4].

O excesso de radiação emitido por explosões solares é detectado por diversos telescópios e sensores, como XRS (*X-ray sensor*), nas bandas de 1-8 Å e 0,5-4 Å, em satélites como GOES (*Geostationary Operational Environmental Satellite*) e registrado em imagens obtidas pelo telescópio SDO [13]. Esse telescópio obtém intensidades de comprimentos de onda invisíveis ao olho nu, sendo cada comprimento convertido em cor visível. Exemplos dessas estão na Figura 1a, correspondentes aos comprimentos de onda 131, 171, 193 e 304 Å registrados às 16:46 UTC de 14/05/2024. Além da radiação, o campo magnético solar também é inferido por diversos satélites e sua magnitude é registrada em imagens HMI (*Helioseismic and Magnetic Imager*) do SDO. Enquanto os parâmetros das regiões ativas são calculados a partir das componentes do campo, resultando nas séries temporais SHARP (*Space-Weather HMI Active Region Patches*) [2]. Explosões solares são classificadas de acordo com o máximo de emissão do fluxo (em  $W/m^2$ ) de raios X na banda 1-8 Å do GOES. Os eventos são classificados em A, B, C, M e X seguindo uma escala logarítmica de  $10^{-7}W/m^2$  a  $10^{-4}W/m^2$ . Por exemplo, um caso com fluxo máximo em  $3,1 \times 10^{-5}W/m^2$  é classificado como M3.1. Note-se que esta classificação não considera a duração dos eventos e, tampouco, a energia total irradiada pelas explosões.



### 3 Aprendizado de Máquina

Conceitos como inteligência artificial e aprendizado de máquina remontam aos anos 1940 com a ideia de neurônio artificial [11] e o processo de aprendizado humano por repetição. Ou seja, realizar uma ação e repeti-la com alguma modificação até que o objetivo seja atingido com algum grau de acerto e o indivíduo seja considerado treinado.

Um neurônio artificial pode ser visto como uma variável real aplicada em operações pré-definidas quando conectado a outro. O conjunto de neurônios e conexões constitui as redes neurais artificiais. Apesar de individualmente simples, o conjunto massivo de neurônios e conexões permite à rede modelar fenômenos complexos [1]. A Figura 4a representa um bloco de construção de uma rede totalmente conectada, considerando um vetor  $\vec{x} = (x_1, \dots, x_7)$  (com 7 neurônios) na camada  $L - 1$  e um vetor  $\vec{y} = (y_1, \dots, y_5)$  (com 5 neurônios) na camada  $L$ . Cada estado  $y_i$  é calculado usando os estados  $x_j$  dos neurônios da camada anterior por uma função de ativação  $f$  como na Equação 1

$$y_i = f(\vec{x} \cdot \vec{w} + b_i), \quad (1)$$

onde  $\theta^{(L)} = (\vec{w}, \vec{b})$  compõe os parâmetros (pesos e vieses) da camada  $L$ .




Figura 4: Comparação de a) blocos de construção de rede neural totalmente conectada e b) rede neural convolucional. Fonte: adaptado de [1] e [8].

Em um fluxo (*pipeline*) completo, um ou mais blocos, como da Figura 4a, são combinados com uma entrada e uma saída. A quantidade de camadas determina a profundidade da rede, enquanto a repetição do fluxo consiste no treinamento. Em cada rodada de repetição completa (época), os parâmetros  $\theta$  são ajustados a fim de otimizar uma função de perda. Essa última advém do erro entre a saída obtida e a desejada (se aprendizado supervisionado), da métrica de estabilidade (se aprendizado não supervisionado) ou da regra de pontuação (se aprendizado por reforço).

A ampliação do número de camadas leva à solução de problemas cada vez mais complexos. Porém, isso pode causar inviabilidade computacional devido ao crescimento do número de operações e parâmetros. Uma solução é a arquitetura de rede neural convolucional (CNN) [8], na qual o bloco da Figura 4a é reorganizado para o da Figura 4b. No caso, a camada  $L - 1$  torna-se um cubo (*tensor*) de dimensão  $C \times N \times N$ ; os parâmetros  $\theta$  estão em  $M$  núcleos (*kernel*) de dimensão  $C \times K \times K$  ( $K < N$ ); os neurônios da camada  $L$  resultam em um cubo de tamanho  $N \times N \times M$ ; e a operação produto escalar da Equação 1 é substituída pela convolução [1].

Vê-se que um cubo com  $C = 1$  é uma matriz, enquanto para  $C > 1$  o cubo é um conjunto de  $C$  matrizes (canais) de dimensão  $N \times N$ . Essa nomenclatura é ligada às imagens digitais, mas entradas de séries temporais ou outros dados em uma dimensão também podem ser reorganizados

em matrizes ou cubos. Isso porque as CNNs são invariantes ao deslocamento (*shift*), detectando características independentemente do posicionamento dos dados [1]. Outra vantagem da CNN é que pode-se ter  $M = 1$  e  $K$  muito menores que  $N$ , reduzindo (muito) a dimensionalidade e o número de operações. Isso ocorre porque os pesos são compartilhados entre os neurônios de uma camada e não mais em cada conexão. Agora, as incógnitas a serem otimizadas são os núcleos, remetendo aos filtros convolucionais no contexto de processamento de imagens [12]. Para o entendimento do processo de treinamento e atualização dos pesos, pode-se construir um modelo Perceptron [15] que reproduza aplicações de portas lógicas como AND, OR e NOT.

## 4 Panorama da Produção Científica Brasileira

A fim de traçar um panorama da pesquisa brasileira nesta área, realizou-se um levantamento de artigos publicados e de projetos com fomento aprovado. Primeiramente, utilizou-se os portais Periódicos CAPES<sup>6</sup>, e *Web of Science*<sup>7</sup>, considerando o ano de publicação após 2010. Para destacar a produção nacional, o Periódicos CAPES oferece um filtro automático, enquanto no *Web of Science* verificou-se a afiliação dos autores. As palavras-chave e respectivas quantidades categorizadas constam na Tabela 1.

Tabela 1: Quantidades de artigos após o ano 2010. Cada recorte de produção nacional está indicado entre parênteses. Fonte: Periódicos CAPES e *Web of Science* (WoS).

Palavras-chave	Periódicos CAPES		
	Revisados	Não Revisados	WoS
solar flare, machine learning	921 (13)	92 (7)	192 (5)
solar flare, neural network	83 (2)	16 (3)	150 (3)
solar flare, deep learning	80 (2)	7 (2)	120 (3)
solar flare, machine learning, neural network	60 (0)	12 (1)	52 (0)
solar flare, machine learning, deep learning	59 (1)	5 (1)	54 (2)
explosões solares	3 (3)	4 (4)	–

A partir da Tabela 1, vê-se que a produção nacional aproxima-se de 1,88% dos artigos revisados por pares, sendo que há cenários com apenas um ou nenhum trabalho nacional. Essa porcentagem é abaixo do índice de participação brasileira na ciência mundial, que foi de 2,78% em 2021 e 2,46% em 2022 [10]. Os cenários com menos trabalhos nacionais são aqueles que envolvem redes neurais (*neural network*) e aprendizado profundo (*deep learning*), o que motiva a redação deste artigo. Duas particularidades dos Periódicos CAPES são a possibilidade de localizar trabalhos em português e trabalhos não revisados (em geral, de eventos). Ainda que esses trabalhos possam parecer menos relevantes, são úteis para estudos iniciais.

Além disso, foi realizada a análise dos autores e filiações nos 16 artigos distintos identificados como revisados por pares e de produção nacional no levantamento via Periódicos CAPES. Nessas publicações, há 57 autores distintos, sendo 37 (65%) com filiação em instituição nacional. A quantidade de artigos ao longo do tempo consta na Figura 5a, que traz ainda recortes de trabalhos com filiações internacionais e nacionais (vermelho), nacionais distintas (verde) e apenas uma instituição nacional (azul). As quantidades de autores por instituição nacional constam na Figura 5b.

Com relação à Figura 5a, vê-se o aumento de publicações com autoria de uma única instituição ao longo dos anos. Além disso, pode-se observar a influência das restrições da pandemia de Covid-

<sup>6</sup><http://www.periodicos.capes.gov.br/>, acessado em 07/03/2025

<sup>7</sup><http://webofscience.com/>, acessado em 07/03/2025

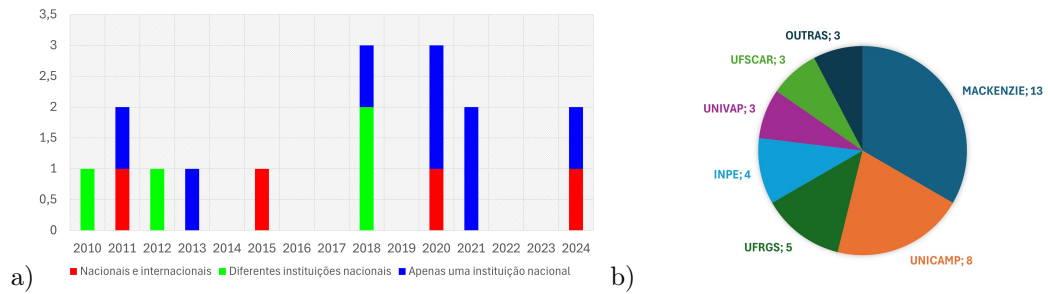


Figura 5: Quantidades de a) produção nacional após o ano 2010 e b) de autores por instituição. Fonte: do autor a partir de levantamento no Periódicos CAPES.

19 (2020 e 2021), que provocaram zero publicações em 2022 e 2023. Mesma hipótese que justifica a queda na produção nacional de modo geral, em 2022 ante 2021 [10].

Já a Figura 5b indica quais instituições nacionais possuem pesquisadores nessa área, com destaque para Mackenzie, UNICAMP, UFRGS e INPE. Os agradecimentos das 16 publicações nacionais analisadas indicam a origem de fomentos, como CAPES (bolsa de estudos), CNPq (universal e bolsa produtividade), Fapergs, Fapesp e Mackpesquisa, além de algumas agências internacionais. Ampliando essa busca, foram localizados projetos usando a palavra-chave “explosão solar” na Biblioteca Virtual da FAPESP<sup>8</sup>. Nesse tema, identificaram-se sete projetos de auxílio à pesquisa regular com vigência a partir de 2002 e finalização mais recente em 2020. Desses, 5 foram sediados no Mackenzie, enquanto os outros 2 foram sediados no INPE e na UNIVAP. Atualmente, não há projeto em vigência na Fapesp. Enquanto o CNPq e a CAPES não disponibilizam dados de projetos financiados de modo equivalente aos da Fapesp, que permitam um levantamento mais amplo.

## 5 Considerações Finais

Este trabalho apresentou uma revisão bibliográfica sobre o fenômeno explosões solares e o aprendizado de máquina, com destaque para fontes de dados e referências importantes para consultas futuras. Além disso, realizou-se um levantamento em Periódicos CAPES e *Web of Science* a fim de traçar um panorama das publicações nacionais envolvendo esses temas. Os resultados demonstram quais instituições nacionais possuem experiência e oportunidades de pesquisa nesta área. Observa-se ainda que a produção nacional sobre o tema é baixa e há necessidade de ações para a ampliação e diversificação de financiamento, a fim de fomentar a formação de novos recursos humanos nacionais nesta linha de pesquisa. Incentivos a novos pesquisadores e ações de internacionalização também são bem-vindos para aprimorar o número de publicações em parceria com autores de instituições internacionais. Bem como, ampliar levantamentos envolvendo outras instituições de fomento e áreas correlatas pode melhorar o direcionamento dessas estratégias. Espera-se, assim, incentivar novas pesquisas e a formação de recursos humanos, combinando essas linhas de pesquisa.

## Agradecimentos

MWSO agradece apoios institucionais IFSP e INPE. TMF agradece CAPES PROSEC. PJAS agradece CNPq (305808/2022-2), MackPesquisa (231017) e FAPESP (2022/15700-7). MRS agradece CNPq (306995/2021-2). LV agradece CNPq/MCTI (422776/2021-1), TED-004/2020-AEB e PO-20VB.0009.

<sup>8</sup><https://bv.fapesp.br/pt/pesquisa/buscador/>, acesso em 20/02/2025.

## Referências

- [1] A. A. Ramos et al. “Machine learning in solar physics”. Em: **Living Reviews in Solar Physics** 20.4 (2023). DOI: 10.1007/s41116-023-00038-x.
- [2] M. G. Bobra et al. “The Helioseismic and Magnetic Imager (HMI) Vector Magnetic Field Pipeline: SHARPs – Space-Weather HMI Active Region Patches”. Em: **Solar Physics** 289.9 (2014), pp. 3549–3578. DOI: 10.1007/s11207-014-0529-3.
- [3] E. Camporeale. “The Challenge of Machine Learning in Space Weather: Nowcasting and Forecasting”. Em: **Space Weather** 17.8 (2019), pp. 1166–1207. DOI: <https://doi.org/10.1029/2018SW002061>.
- [4] E. W. Cliver et al. “Extreme solar events”. Em: **Living Reviews in Solar Physics** 19.2 (2022). DOI: 10.1007/s41116-022-00033-8.
- [5] Peter T. Gallagher, Eoin Carley e Aoife McCloskey. **www.SolarMonitor.org**. Online. Acessado em 10/03/2025, <http://www.solarmonitor.org>.
- [6] N. L. S. Jeffrey et al. “The development of lower-atmosphere turbulence early in a solar flare”. Em: **Science Advances** 4.12 (2018), eaav2794. DOI: 10.1126/sciadv.aav2794.
- [7] S. Krauss et al. “SODA – A tool to predict storm-induced orbit decays for low Earth-orbiting satellites”. Em: **J. Space Weather Space Clim.** 14 (2024), p. 23. DOI: 10.1051/swsc/2024022.
- [8] Y. Lecun et al. “Gradient-based learning applied to document recognition”. Em: **Proceedings of the IEEE** 86.11 (1998), pp. 2278–2324. DOI: 10.1109/5.726791.
- [9] K. D. Leka et al. “A Comparison of Flare Forecasting Methods. II. Benchmarks, Metrics, and Performance Results for Operational Solar Flare Forecasting Systems”. Em: **The Astrophysical Journal Supplement Series** 243.2, 36 (2019), p. 36. DOI: 10.3847/1538-4365/ab2e12.
- [10] F. Marques e C. Queiroz. “Produção científica brasileira sofre retração”. Em: **Revista Pesquisa Fapesp** 331 (2023).
- [11] W. S. McCulloch e W. Pitts. “A logical calculus of the ideas immanent in nervous activity”. Em: **The bulletin of mathematical biophysics** 5 (1943), pp. 115–133. DOI: 10.1007/BF02478259.
- [12] M. W. S. Oliveira. “Imagens e Inteligência Artificial: Um Pouco De Matemática Nesta História”. Em: **Caderno de Resumos Expandidos - III Encontro do PGMAT**. Ed. por S. M. S. Afonso e T. de Melo. Vol. 2025. IGCE-UNESP, 2025, pp. 66–73.
- [13] W. D. Pesnell, B. J. Thompson e P. C. Chamberlin. “The Solar Dynamics Observatory (SDO)”. Em: **Solar Physics** 275 (2012), pp. 3–15. DOI: 10.1007/s11207-011-9841-3.
- [14] E. R. Priest e T. G. Forbes. “The magnetic nature of solar flares”. Em: **Astronomy and Astrophysics Review** 10.4 (2002), pp. 313–377. DOI: 10.1007/s001590100013.
- [15] F. Rosenblatt. “The perceptron: A probabilistic model for information storage and organization in the brain.” Em: **Psychological Review** 65.6 (1959), pp. 386–408. DOI: 10.1037/h0042519.
- [16] V. M. Souza et al. “Bases teóricas da reconexão magnética”. Em: **Revista Brasileira de Ensino de Física** 38.2 (2016), e2301. DOI: 10.1590/S1806-11173812132.
- [17] A. Valio. “Sob a influência do Sol: como o clima espacial afeta nosso planeta”. Em: **Cadernos de Astronomia** 5.2 (2024), pp. 30–45. DOI: 10.47456/Cad.Astro.v5n2.45935.